# PATENT ABSTRACTS OF JAPAN

(11)Publication number:

03-014184

(43)Date of publication of application: 22.01.1991

(51)Int.CI.

G06F 15/62 G06F 15/40

(21)Application number: 01-148463

(71)Applicant : FUJI XEROX CO LTD

(22)Date of filing:

13.06.1989

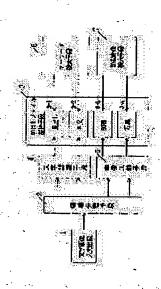
(72)Inventor: HAYASHI YUKIO

## (54) DOCUMENT IMAGE REARRANGEMENT FILING DEVICE

#### (57)Abstract:

PURPOSE: To efficiently execute a retrieval by extracting and separating automatically areas of different attributes such as a heading, a text, a chart, a photograph, etc., in a document image and accumulating them at every item so that the retrieval can be executed by a suitable retrieving method at every area of the attributes.

CONSTITUTION: An input document image inputted by scanning a newspaper, etc., by a document image input means 1 is separated into each attribute area of a heading 3-1, a text 3-2, a chart 3-3, and a photograph 3-4. Subsequently, as for the areas of the heading 3-1 and the text 3-2, a character recognition processing is performed and they are converted to :-code data, and as for the areas of the chart 3-3 and the photograph 3-4, an image compression processing is performed, and thereafter, they are brought to filing to each separate attribute item. In the retrieving means 6, or the retrieving means 7, the retrieval can be executed by selecting one of a key word retrieval to the heading 3-1 or the text 3-2, and a retrieval of a similar image to the chart 3-3 and the photograph 3-4. In such a way, the retrieval/display time for a document image is shortened, and also, by rearranging the document image, the data compression can be executed.



#### **LEGAL STATUS**

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2000 Japanese Patent Office

#### SPECIFICATION

#### 1. TITILE OF THE INVENTION

DOCUMENT IMAGE RE-ARRANGEMENT FILING APPARATUS

#### 5 2. WHAT IS CLAIMED IS:

10

A document image re-arrangement filing apparatus comprising:

document image input means for inputting document image;
region dividing means for automatically extracting from
the document image input by said document image input means
different attribute regions such as a headline region, a text
region, a drawing region and a photograph region, and dividing
them;

itemized file storing means for accumulating and storing

items such as the headline, the text region, the drawing region

and the photograph region, extracted and divided by the region

dividing means

retrieving means for retrieving data of the items stored in the itemized file storing means, by item;

- desired document image by retrieval of the retrieving means, and re-arranging the data in the items to output the entire document image.
  - 3. DETAILED DESCRIPTION OF THE INVENTION
- 25 [FIELD OF THE INVENTION]

The present invention relates to a document image re-arrangement filing apparatus capable of automatically extracting images in regions consisting of various attributes such as a headline, a text, a drawing, a photograph and the like, to store item by item, re-arranging each of the entire item in image such as a scrap of a newspaper.

### [PRIOR ART]

10

20

25

It is proposed now for an apparatus that files document images such as a scrap of a newspaper to employ a system for automatically extracting the complicated layout shapes according to each attribute (a headline, a text, a drawing, a photograph) region of the document image, and re-arranging the image data compactly.

For example, there is proposed a database editing and controlling system that extracts image of a newspaper that is input by an image input apparatus, as a pattern with use of a man-machine interface; stores the image data after structuring the data by structurally newriting the data to reduce the data amount, and re-edits the data in use in accordance with the object (The Institute of Electronics, Information and Communication Engineers GIHOU PRL84-101, pp.65-72).

Similarly, an automatic layout system capable of automatically extracting the document structure such as a hierarchical structure based on the concepts such as a title, a chapter and a paragraph, and a reference structure between

a text and drawings by using format information of the document or keywords, and executing formatting or layout of the document with use of a format based on the document structure and knowledge about layout technique (JOHOSHORI ASSOCIATION "DOCUMENT PROCESSING AND HUMAN INTERFACE", 20-3, September 8, 1988).

[OBJECT TO BE SOLVED BY THE INVENTION]

In order to obtain the desired document image with use of the above-mentioned techniques, however, the entire document image has to be retrieved and checked, which is a so troublesome job requiring a long period of time. Further, the image document contains various data such as a headline, a text, a drawing, a photograph and the like in a mixed manner, so that in some cases, it turns out wasteful from a viewpoint of data storage system.

The present invention intends to provide a document image re-arrangement filing apparatus capable of reducing a period of time required for retrieving and displaying the document image, and compressing data by re-arranging the document image data to remove redundant space in the document.

### 20 [MEANS OF SOLVING THE PROBLEMS]

5

25

As shown in Fig. 1, the document image re-arrangement filing apparatus according to the present invention comprises: document image input means 1 for inputting by scanning document image such as a scrap of a newspaper; region dividing means 2 for automatically extracting from the document image input by

the document image input means 1 different attribute regions such as a headline region (3-1), a text region (3-2), a drawing region (3-3), a photograph region (3-4) and the like, and dividing them; itemized file storing means 3 for accumulating and storing items such as the headline, the text region, the drawing region, and the photograph region, extracted and divided by the region dividing means 2; retrieving means (6, 7) for retrieving data of the items stored in the itemized file storing means 3, by item; document image re-arrangement means 8 for retrieving desired document image by retrieval of the retrieving means (6, 7), and re-arranging the data in the items to output the entire document image.

### [EFFECT]

5

The input document image data input by scanning a newspaper or the like with use of a document image input means 1 is divided into each attribute region such as a headline 3-1, a text 3-2, a drawing 3-3, and a photograph 3-4 by a region dividing means. 2, and then positional data of the rectangular regions enclosing the respective regions is then extracted: coordinates (x, y) 20 of an upper left corner of the rectangular region; a width w; and a height h. At this time, it is determined whether the document is written vertically or horizontally. Subsequently, the attribute regions the headline 3-1 and the text 3-2 are subjected to the character recognition process to be converted 25 into code data, and the attribute regions the drawing 3-3 and

the photograph 3-4 are subjected to the image compressing process, and the image data is filed into the corresponding items. retrieving is executed by either a retrieving means 6 or a retrieving means 7: keyword retrieving (substring matching for registered portion key) executed for the headline 3-1 or the text 3-2 by retrieving means 6; and analogous image retrieving executed for the drawing 3-3 and the photograph 3-4 by retrieving means 7. During retrieving, only one of the image data among the headline 3-1, the text 3-2, the drawing 3-3 and the photograph 3-4, which is now retrieved is displayed. When the retrieving has finished, a re-arrangement processing means 8 executes the re-arrangement process for the entire document and displayed. The re-arrangement processing means 8 executes repeatedly the re-arrangement of the retrieved data to arrange the retrieveddata from the upper right towards left in order of the headline 3-1, the text 3-2, the drawing 3-3 and the photograph 3-4, and a line is filled with the data, arrange the data to the other paragraph (in the horizontally written document, from the upper left toward right).

20 Figs. 2 and 3 respectively show the division result of the image data into the attribute regions and the re-arrangement result.

#### [EMBODIMENTS]

. 5

10

15

The technical idea of the present invention will be described below while referring to Fig. 1.

In this drawing, the document image input means 1 scans image document such as a scrap of a newspaper and input the image data, and the region dividing means 2 automatically extracts the attributes of the image data from the input document image, for example, the headline 3-1, the text 3-2, the drawing 3-3and the photograph 3-4. Among the document image extracted with each attribute items, the headline 3-1 and the text 3-2 are recognized as characters by a character recognition means 4 to be converted into character codes, and then stored in an itemized  $\cdot$ file storing means 3. When the extracted document image is image data, the image data compressing means 5 compresses the data to be stored in the itemized file storing means 3. If the stored image needs to be displayed, the data can be retrieved with use of the keyword retrieving means 6 for retrieving character data from the headline 3-1 and the text 3-2 as by item and the analogous image retrieving means 7 for retrieving image data from the drawing 3-3 and the photograph 3-4. The document image re-arrangement means 8 displays the final retrieving result obtained by these retrieving means.

5

10

15

20 The regions can be arbitrarily recognized and divided according to the difference of the attributes of the regions; area, density, the number of edges, or the like of a text region, a headline region, a drawing region, a photograph region and the like.

25 Fig. 4 is a block diagram showing the constitution example

of the region dividing means 2. The constitution shown in the diagram is based on the technical inventions disclosed in Japanese Patent Application No. SHO 63-252920, Japanese Patent Application No. SHO 63-291095, and Japanese Patent Application No. HEI 1-87039 (inventor of all the applications: Yutaka NAKAMURA) by the applicant of the present application, comprises: binarizing means 201; rectancularized region image storing memory for 202 storing the rectancularized image; rectancularizing means .203 for rectancularizing image; binarized image memory 204 for storing binarized image; isolated point removing means 205 for removing isolated points from the binarized image; outline extracting means 206 for extracting outline of the image after removing the isolated points; outline image memory 207 for storing the extracted outline image; and 15 , image region recognizing means for recognizing image region on 1.00the basis of the data stored in the memories 202, 204, and 207. The image region recognizing means has rectangular region address generating section 208, black pixel calculating section 209 and 210, text character recognition section 211, rectangular area 20 calculating section 212, comparing section 213, area comparator (headline/drawing distinguishing section) 214, comparator (photograph/character-linearimage distinguishing section) 215 and the like.

10

The image is input by a scanner or the like in a multivalued 25 The input image data is binarized by the binarizing means

201. The binarized image data is subjected to the rectancularizing process executed by the rectancularizing means 203, wherein the black pixels are connected and the connected black pixels are enclosed by a rectangular. The obtained rectangular region is stored in the rectancularized region image storing memory 202, and used as an image recognizing unit.

After the binarizing process, the isolated points of the binarized image data are removed by the isolated point removing means 205, and the outline, i.e., the edge of the image is then extracted by the outline extracting means 206, and stored in the outline image memory 207.

The recognition of the region is performed as follows: at first, the text character recognition section 211 recognizes the text area by inferring the character height of the text on the basis of the distribution of the heights of the rectangular portions in unit of the region enclosed by the rectangular obtained by the rectancularizing means 203, and divides the text areas. Next, the headline regions, the drawing regions, and the photograph regions other than the text regions are recognized on the basis of the area, the density and the edge of the rectangle. That is, the rectangular region address generating section 208 generates the addresses of the pixels in the rectangular regions other than the text region on the basis of the rectancularized image data read from the rectangular region are read from memory 202. The pixels in the rectangular region are read from

20

25

the binarized image memory 204 and the outline image memory 207 in accordance with the generated addresses. The number of the black pixels in the read pixels are respectively calculated by the black pixel calculating sections 209 and 210. The calculated number of the black pixels in the binarized image in the rectangular portion is compared with the number of the black pixels in the outlined image by the comparing section 213 to obtain the ratio thereof. The comparator 215 compares the ratio obtained by the comparing section 213 with a predetermined threshold value. When the ratio is larger than the threshold value, the image is determined as a character-linear image region, and when the ratio is smaller than the threshold value, the image is determined as a photograph region.

When the image is determined as a character-linear image region, the image is further determined on the basis of the area of the rectangle whether it is the headline region or the drawing region. In order to distinguish the image regions in this way, the area of the rectangular region is calculated by the rectangular area calculating section 212 on the basis of the rectangularized region image read from the rectangularized region image storing memory 202. Subsequently, the area comparator (headline/drawing distinguishing section) 214 compares the calculated area of the rectangular region with a predetermined threshold value. When the calculated value is smaller than the threshold value, the rectangular region is

determined (recognized) as the headline region, and when the calculated value is larger than the threshold value, the rectangular region is determined as the drawing region.

On the basis of the determination (recognition signal), 5 the image signal of each region is divided and extracted from the input image stored in the image memory or the like, and subjected to necessary processes such as character recognition, code compression, and addition of the attribute information for retrieving, then registered in the itemized file storing section 10 That is, the scan-in input image is divided into the attribute region such as the headline region 3-1, the text region 3-2, the drawing region 3-3, and the photograph region 3-4, and the positional data of the rectangular regions is then extracted: coordinates (x, y) of an upper left corner of the rectangular 15 region; a width w; and a height h. At this time, it is determined whether the document is written vertically or horizontally. Subsequently, the headline region and the text region are subjected to the character recognition process by the character recognition means 4 so as to be converted into code data.  $oldsymbol{20}$  drawing region and the photograph region are subjected to the image compressing process by the image data compressing means The itemized file storing means 3 files the processed data of the attribute regions by item.

The registered image in the above-described manner is performed by the keyword retrieving means 6 in accordance with

the keyword retrieving (substring matching for registered portion key) to retrieve the required image. The retrieval of the drawing or photograph is executed by the analogous image retrieving means 7.

5 An example of the analogous image retrieving executed for the drawing 3-3 and the photograph 3-4 will then be described in detail with reference to Figs. 5 and 9. The example is based on the description disclosed in Japanese Patent Application No. HEI 1-113829 (inventor: MAKOTO HIROSE) by the applicant of the 10 present application, which is advantageous in that the required image data can be retrieved at a high speed.

Fig. 5 is a block diagram showing the schematic constitution of an embodiment the image retrieving apparatus capable of performing the above-mentioned analogous image 15 retrieving according to the present invention. The image retrieving apparatus comprises: an image input device 25 used by a user or an administrator for inputting image; a display device 26 for displaying image or the other information to the user or the administrator; a calculation processor 27 for calculating the degree of the agreement of the images and 20 controlling the order of displaying the retrieved image or entire apparatus; an image output device 28 for outputting the retrieved image in a form of printing; a control instruction input device 29 used by the user to input the tolerance of the image agreement determination; and a memory device 30 for storing image and

25

information.

5

25

In order to execute the analogous image retrieving effectively, the drawing and photograph are processed to add the characteristic information in registering in the itemized file storing section 3.

The registering operation will be described at first. Fig. 6 shows an example of the structure of the two-dimensional binarized image information sent from the image input device 25. The image information is displayed as image by the display 10 device 26. The whole image information is binarized data of M x N wherein 0 expresses white pixel, and 1 expresses black The calculation processor 27 prepares character information 32 constituted in an architecture shown in Fig. 7 on the basis of character quantity obtained from the quantization  $\cdot$  $\sim 15$  of the number of value 1 every small region of K × L in the respective The character information 32 and the M  $\times$  N image information 33 are stored in the memory device 30. In this manner, as shown in Fig. 5, a character information group 34 and the image data group 35 of a plenty of images are stored in the memory device 30. The head image number 31 is an arbitrary number given 20. for the calculation processor 27 to recognize a plurality of image data.

The retrieving process of the image data will then be described next with reference to the operation process flow chart shown in Fig. 9. The number 1 of the images desired by users

is input into the control input device 29 as the tolerance of the image agreement determination (1).

Upon receiving the image as the retrieving condition, the calculation processor 27 prepares character information  $a_{K1}$  of the image as the retrieving condition, in the same manner as the registration (2).

5

After setting j as 1, the value of a register  $D_I$  to which  $I_{th}$  value is input in order of the degree of disagreement from the smaller one is set as  $^*K \times L$  (3).

The character quantity  $b_{JK1}$  of the image number j is calculated (4). As shown in Fig. 8, In the case where the character quantity is calculated in registering the image and registered together with the image as the index of the image, the registered value is read from the memory device 30.

The calculation processor 27 calculates the degree of the disagreement  $D_J$  between the  $j_{th}$  image and the image to be retrieved serially from the image number 1 (5).

In every time when the value  $D_J$  is obtained, the value  $D_I$  as the  $I_{th}$  value in order of the degree of the disagreement from the smaller one is compared with the value  $D_J$  (6).

When  $D_J > D_I$ , the desired image is not present in the group to the  $I_{th}$  image, and thus a process on the next image is executed. At this time, the value j is add with 1 (7).

When the result of the comparison is  $D_J \le D_I$ ,  $D_I$  is replaced with  $D_J$  (7). The number of images from the image having the

smallest disagreement value to the  $I_{th}$  image are stored in the memory (8). A process on the next image is then executed and the value j is add with 1 (9).

Finally, after calculating the degree of the disagreements of all the stored images, the image having the smaller disagreement degree is displayed in the display device 26.

The calculation of the degree of the disagreements between the character information of the images in the character information group 34 and the character information of the image to be retrieved will be described below. The character information comprises the character quantity expressed by the image number 31 and the matrix having K rows and L columns. character quantity of the image to be retrieved is expressed as  $a_{K1}$  (k = 1 to K, 1 = 1 to L), and the character quantity of 15 the j $_{
m th}$  image in the character information group 14 to be retrieved is expressed as  $b_{jkL}$  (k = 1 to K, 1 = 1 to L). Assuming the number of l in each of the small regions is quantized as binary value, the degree of the disagreements between the image to be retrieved and the jth image is obtained by the calculation expressed by the following formula:

$$D_{J} = \Sigma \Sigma (a_{K1} \oplus b_{\uparrow kL})$$

5

10

20

In other words, the total sum of the exclusive OR of the corresponding elements is defined as the disagreement. symbol  $\oplus$  denotes the exclusive OR.

25 Assuming the number of 1 in each of the small regions is quantized as multivalued, more specifically,  $a_{K1}$  and  $b_{jkL}$  are multivalued, the degree of disagreements between the image to be a condition and the  $j_{th}$  image is obtained by the calculation expressed by the following formula:

 $D_{J} = \Sigma \Sigma | (a_{K1} - b_{jkL}) |$ 

10

15

20

25

Prior to the output of the image as the result of the retrieval, the re-arrangement of the entire document comprising the headline 3-1, the text 3-2, the drawing 3-3 and the photograph 3-4 is then performed. Figs. 10 and 11 shows the process flow of the re-arrangement. The processes shown in Figs. 10 and 11 are connected at (a) and (b).

At first, the headline storing position in the itemized file storing means 3, which is assigned to the retrieved document image is searched to determine whether or not the headline 3-1 is present (11).

When the headline 3-1 is present, it is determined whether the headline 3-1 is written vertically or horizontally (12). When the headline 3-1 is written vertically, the read headline is re-arranged in accordance with the vertical re-arrangement procedure (13). When the headline 3-1 is written horizontally, the read headline is re-arranged in accordance with the horizontal re-arrangement procedure (14).

In spite of the fact that the headline 3-1 is written vertically arranged (13) or horizontally arranged (14), the headline storing position is further searched to determine

whether or not the other headline is present (11).

5

10

15

25

When the other headline is not present in the storing means, the re-arrangement has finished and the re-arrangement of the character lines of the text will be executed next. At this time, the next row is set as the upper right end coordinate of the character lines (15).

The storing means is searched to determine whether or not the other character line is present (16). When the character line is present, the right edge space present on the right side of the character line is compared with a predetermined margin provided to the left side (17). When the left margin is smaller than the right space, the re-arrangement of the character line is executed (18). The re-arrangement of the character line is executed such that the position subtracted by the width of a character from the right end of the present character line is determined as the right end of the next character line (19).

When the space on the left side of the character line becomes smaller than the predetermined left margin in the step (17), the paragraph is changed and the right end space of the character line is set again (20). The re-arrangement of the character line is performed in the same manner as in the step (18) (21).

When the other character line to be arranged is not present in the storing means in step (16), the re-arrangement of the drawing and photograph will be executed next. At this time, the upper right end coordinate of the drawing and the photograph

(22).

5

10

15

25

When the drawing or the photograph is present in the document image in step (23), the right edge space present on the right side of the drawing or the photograph is compared with a predetermined margin provided to the left side (24). When the left margin is smaller than the right space, the re-arrangement of the drawing and the photograph is executed (25). The re-arrangement of the drawing and the photograph is executed such that the position subtracted by the width of the drawing and the photograph from the right end of the present drawing or the photograph is determined as the right end of the next drawing or photograph (26).

In the case that the predetermined left margin becomes bigger in step (24), the paragraph is changed and the right end space of the character line is set again (27). The re-arrangement of the drawing or the photograph is performed in the same manner as in the step (25) (28). When it is determined that no more drawing or photograph is present in the storing means, the re-arrangement process has finished (20).

### 20 [ADVANTAGES OF THE INVENTION]

According to the present invention, the different attribute regions such as headline region, text region, drawing region, photograph region or the like in a document image can be automatically extracted from the document image, divided and classified by item (attribute region) to store them. In addition,

in retrieving the stored image data, the image data can be retrieved in accordance with the process suitable for the attribute region to be retrieved. Further, during the retrieval, only the attribute region now retrieved can be displayed. such a retrieving method, the retrieval can be performed so effectively.

Further, the retrieved document image is re-arranged by classifying and collecting them by item, the redundant space in the document can be removed and data can be compressed, and the period of time required for retrieving can be reduced.

## 4. BRIEF DESCRIPTION OF THE DRAWINGS

Fig. 1 is a block diagram showing the constitution of the document image re-arrangement filing apparatus according to the present invention; Figs. 2 and 3 show the modes of filing the 15 respective attribute regions abstracted by the region dividing;  $\sim$ Fig. 4 is a block diagram showing the constitution of the region dividing means; Fig. 5 is a block diagram showing the constitution of the image retrieving apparatus; Fig. 6 shows the structure of the two-dimensional binarized image data; Fig. 7 shows the architecture of the character information; Fig. 8 shows the character information group and the image information group; Fig. 9 is a flow chart of the retrieving process; Figs. 10 and 11 are flow charts of the re-arrangement process by the re-arrangement means 8 shown in Fig.1.

20

- 1 ... document image input means
- 2 ... region dividing means
- 3 ... itemized file storing means
- 4 ... character recognition means
- 5 5 ... image data compressing means
  - 6 ... keyword retrieving means
  - 7 ... analogous image retrieving means
  - 8 ... document image re-arrangement means
- Applicant FUJI XEROX CO. LTD.
- 10 Attorney SHOUICHI IWAKAMI

Drawing

Fig. 1

- (Dheadline
- ②photograph
- 5 3drawing

text (本文)

Fig. 2

2 document image

Fig. 3

10 ②headline

Fig. 4

- ①inputting an image
- ②binarizing means 201
- ③rectancularized region image storing memory 202
- 15 ④binarized image memory 204
  - Srectancularizing means 203
  - 6 isolated point removing means 205
  - Toutline extracting means 206
  - ®outline image memory 207
- - ①comparing section 213
  - ①comparator (photograph/character-linear image distinguishing section) 215
  - ②threshold value

- Marea comparator (headline/drawing distinguishing section) 214
- (5)threshold value
- (6) text character recognition section 211
- Trectangular region address generating section 208
- 5 ®black pixel calculating section 209
  - Prectangular area calculating section 212
  - Fig. 5
  - 20 image input device 25
  - 21 calculation processor 27
- 10 22 control instruction input device 29
  - 23 display device 26
  - 24 image output device 28
  - 25 memory device 30
  - Fig. 6
- **15** 26 N
  - Fig. 7
  - ①image number
  - ②character quantity within the small region in the case of k=1, l=1
- **20** Fig. 8
  - 3 image number 1
  - (4) character information
  - Sthe entire information of the first image
  - 6the entire information of the second image
- 25 The entire information of the j-th image

## Fig. 9

- 8input desired number 1
- $\mathfrak{G}$ prepare character information  $a_{K1}$  of image to be retrieved
- M calculate character quantity  $b_{\mathtt{JK1}}$  of image number j
- ${\bf 5}$  (D)calculate disagreement  $D_{\cal J}$  between  $j_{\, th}$  image and image to be retrieved
  - 1 store number of images from image having the smallest disagreement value to the  $I_{\text{th}}$  image
  - ③process end?
- **10** Fig. 10
  - ①other headline present?
  - ②written vertically or horizontally?
  - ③horizontal re-arrangement procedure
  - ④vertical re-arrangement procedure
- 15 ⑤set upper right end coordinate of character line
  - **©**other headline present?
  - Theft margin is smaller than right space?
  - ®execute re-arrangement of character line
  - 9determine a position subtracted by the width of a character
- - Wiset upper right end coordinate of drawing and photograph
  - Dexecute re-arrangement of character line
  - (1) Change paragraph and set again right end space of character
- 25 line

- (a) = 1
- $(b) = \Box$

Fig. 11

- ③left margin is smaller than right space?
- 5 Mother drawing or photograph present?
  - Dexecute re-arrangement of drawing or photograph
  - (b)determine a position subtracted by the width of drawing or photograph from right end of present drawing or photograph as right end of next drawing or photograph
- 10 Dend re-arrangement of drawing or photograph
  - Bexecute re-arrangement of drawing or photograph
  - (19) change paragraph and set again right end space of drawing or photograph

19日本国特許庁(JP)

① 特許出願公開

# ⑫ 公 開 特 許 公 報(A)

平3-14184

@Int. Cl. 5

識別記号

庁内整理番号

@公開 平成3年(1991)1月22日

G 06 F 15/62 15/40

325 R 530 X 8125-5B 7313-5B

審査請求 未請求 請求項の数 1 (全10頁)

69発明の名称

文書画像再配置フアイリング装置

②特. 願 平1-148463

**20出 願 平1(1989)6月13日** 

700発明者

幸 雄

神奈川県海老名市本郷2274番地 富士ゼロックス株式会社

海老名事業所內

⑪出 願 人 富士ゼロジ

富士ゼロツクス株式会

東京都港区赤坂3丁目3番5号

社

四代 理 人 弁理士 岩上 昇一

明 細 書

1 発明の名称

文書画像再配置ファイリング装置

2 特許論求の範囲

文書画像を入力する文書画像入力手取と、

前記文書画像入力手段により入力された文書画像の見出し、本文、図表、写真等の各異なる属性の領域を自動的に抽出、分離する領域分離手段と、前記領域分離手段により抽出、分離された見出し、本文、図表、写真の各項目を項目ごとに書段、格納する項目別ファイル書稿手段と、

前配項目別ファイル書積手段に整確されている 各項目の内容をそれぞれの項目ごとに検索できる 検索手段と、

前記検索手段の検索によって所望の文書画像を 検索し、各項目の内容を再配置して全体の文書画 像を出力する文書画像再配置手段と、

3 発明の詳細な説明

(産業上の利用分野)

本発明は、新聞切抜等の文書面像において、見出し、木文、図表、写真等異なる属性からなる領域の画像を自動的に抽出し、各項目ごとに書積した後、各項目全体を再配置して出力できる文書画像再配置ファイリング製置に関する。

(従来の技術)

新聞切抜等の文書画像をファイリングする装置において、その複雑なレイアウト形状を文書画像の属性 (見出し、本文、図表、写真) 領域に従って自動的にそれぞれの領域を抽出して、コンパクトに再配置するシステムが提案されている。

たとえば、画像人力装置から入力した新聞画像をマンマシン対話によりパターンとして抽出し、 構造記述によりデータを構造化してデータ勇を削減して書積し、利用時にはその目的に合わせて再 編集できるデータベース編集管理システムがある (個学技報 PRL84-101 P.65~7 2)。

- 2 -

特関平 3-14184(2)

また、文書の形態的情報やキーワードを用いて、 様題、草、節等による階層構造と、本文と図表間 の参照構造等の文書構造の自動抽出を行うことが でき、さらに、文書構造に基づいた書式とレイナ ウト知識を用いて、文書のフォーマッティングや 図表の割付けを行う自動レイアウトシステム等が ある(情報処理研究会 「文書処理とヒューマン インタフェース」 20-3 1988.9.8.

(発明が解決しようとする課題)

しかし、ファイリングされた文書画像から所望 の文書画像を得るためには、文書画像全体を検索 ・チェックしなければならないので、検索に時間 がかかった。また、文書画像には見出し、本文、 図表、写真等が混在しているので、データの書積 として無駄である場合があった。

本発明は文書画像の検索・表示時間を短縮させるとともに、文書画像を再配置することによって 文書中の無駄な余白を取り除いてデータ圧縮をさせることができる文書画像得ファイリング装置を

- 3 -

段2で、見出し3-1、本文3-2、図表3-3、 写真3-4の各属性領域に分離され、それぞれの 領域を囲む矩形の左上端座標(x,y)、幅w、 高さりが抽出される。この時、経費を機費きの判 別もなされる。次に、見出し3-1と本文3-2 との領域については、文字認識処理が施されてコ ゛ードデータに変換され、図表3-3と写真3- 4゜ との領域については、面像圧縮処理が施された後、 各属性項目別にファイリングされる。 検索手段 6 では、見出し3-1あるいは本文3-2に対する キーワード検索(登録済部分キーによる部分一致 - ストリングマッチング)、または検索手段?では、 図表3-3、写真3-4に対する類似面像の検索 のいずれかを選んで検索できる。検索時には検索 対象とした見出し3-1、本文3-2、図表3-3、写真3-1のいずれかのみ表示し、検索終了 時には文書画像全体を再配置処理手段8で再配置 処理を施して表示する。再配置処理手段8では、 見出し3-1、本文3-2、図表3-3、写真3 - 4の順に、右上から左に配置し、左端になった

提供することを目的とする。

(課題を解決するための手段)

本発明は、第1図に示すように、新聞切抜等の 文書画像をスキャン入力する文書画像入力手段1 と、前記文書画像入力手段1により入力された文 審画像の見出し(3 − 1)、本文(3 - 2)、図 表 (3-3)、写真(3-4) 等の各異なる阈性 の領域を自動的に抽出、分離する領域分離手段 2 と、前記領域分離手段?により抽出、分離された 見出し、本文、図表、写真等の各項目を項目ごと に蓄廣、格納する項目別ファイル蓄積手段3と、 前記項目別ファイル蓄積手段3に審積されている 各項目の内容をそれぞれの項目ごとに検索できる 検索手段(6、7)、前記検索手段(6、7)の 検索によって所望の文書画像を検索し、各項目の 内容を再配置して全体の文書画像を出力する文書 (作 用・)

文書画像人力手段 1 によって新聞等をスキャン して入力された入力文書画像は、領域分離処理手

-- 4 ....

ら段階を変える(機書きの場合は左上から右に配置していく) 事をくり返す。

第2図および第3図には各鼠性領域に分離された結果と再配置された結果の一例をそれぞれ示す。. (忠 統 例)

特開平 3-14184(3)

と、面像として図表 3 - 3 および写真 3 - 4 を検索する類似面像検索手段 7 とにより検索できるようになっている。そして、文書画像再配置手段 8 には、これらの検索手段によって、最終検索結果を出力表示する。

本文学領域、見出し領域、図数領域、および写 真領域のそれぞれの大きさ、領域内の濃度、エッ ジの数…等の属性の相違に着目することにより、 領域の顧別および分離を任意に行うことができる。

野 4 図は領域分離手段 2 の構成例を示すブロック 2 である。これは本出願人の出版になる特願昭昭 6 3 - 2 9 1 0 9 5 号 (発明者 中村豊)、特願昭昭 1 - 8 7 0 3 9 号 (発明者 中村豊)、特額平1 - 8 7 0 3 9 号 (発明者 中村豊) 等の明知書に開示の技術によって構成した一例であり、2 値化手段 2 0 1、矩形化処理された面像を格動する矩形化領域画像メモリ 2 0 2、矩形化処理を行う矩形化処理手段 2 0 3、2 値化された画像を記憶する 2 値画像メモリ 2 0 4、2 値化された画像に対して孤立点除去を施す孤立点除去手段 2 0

5、孤立点除去後の画像に対して輪郭抽出処理を 施す輪郭抽出手段 2 0 6、抽出された輪郭画像を 記憶する輪郭画像メモリ 2 0 7、各画像メモリ 2 0 2、 2 0 4、 2 0 7の記憶内容に携づいて画術 像領域の判定を行う領域離別手段とからなってい る。領域判定手段は、矩形領域アドレス発生部 2 0 8、黒画素計数部 2 0 3、 2 1 0、本文文字識 別部 2 1 1、矩形面積算出部 2 1 2、比算出部 2 1 3、面積比較部(見出し/図表識別部) 2 1 4、 比比較部(写真/文字級画像識別部) 2 1 5 等か らなっている。

人力画像はスキャナ等より多値で入力される。 画像入力データは2値化処理手段201により2 値化処理される。2値化された画像は矩形化処理 手段203によって黒西霧を連結し連結した領域 を矩形で囲む矩形化処理を施され、得られた頻形 領域は矩形化領域画像メモリ202に記憶され、 画像の識別単位として利用される。

また、2位化された画像は、孤立点除去手段2 05により孤立点を除去された後、暗郭抽出手段

- 7 -

- 8 <del>-</del>

206により輪郭即ちエッジ部分の抽出処理がなされ、輪郭画像メモリ20に記憶される。

領域の識別は、矩形化処理手段203により得 られた矩形で囲まれた領域を単位として、まず、・・ 本文文字職別部211により、矩形の高さの分布 から本文の文字高さを推定して、本文を識別し、 これを分離する。次に残りの画像中の見出し領域、 図表領域、写真領域を、矩形の大きさ、矩形内の 濃度やエッジから判別する。即ち、矩形領域アド レス強生感208において、本文文字以外の名類 形領域について矩形化領域画像メモリ202から 読み出した矩形化処理した画像に基づき矩形領域 の各画素のアドレスを発生する。発生したアドレ スにより2位面像メモリ204および輪卵面像メ モリ20?からそれぞれ矩形領域内の画案を読み だし、その読み出した画業の黒画第の数をそれぞ れ黒面素計数部209、210で計数する。計数 した矩形内の2位画像の黒画素数と輪郭画像の黒 画素数との比を比算出部 2 1 3 で算出する。比比 妙部215は比算出部213で算出した比を予め

定めたしきい値と比較し、しきい筒よりも大きい 場合は文字線画領域、小さい場合は写真領域と判 定する。

文字線画像と判定されたときは、矩形の大きさによりそれが見出しる。そのために、矩形化処理画像メモリ202から統み出した矩形化処理出部であるかを判定する。そのために、矩形化処理出であるが、近点で変化の面積を矩形面積第出した短形の面積と比較して変化したが、ないときはよりいといいといいといいであると判定(強別)する。比較の結果していばよりも大きいときは、図表領域であると判定(強別)する。比較の結果していばよりも大きいときは、図表領域であると判定(ないは、図表領域であると判定しました。

これらの判定結果(職別信号)に基づいて、イメージメモリ等に記憶されている入力画像から各領域の画像信号が分離抽出され、文字認識や符号 圧縮、検索のだめの属性情報の付加等の必要な処理を縮された後、項目別ファイル書積部3に登録

特開平 3-14184(4)

以上のようにして、登録された面像に対する検索は、見出しあるいは本文に対してはキーワード検索手段 6 によりキーワード検索(登録済部分キーによる部分一致ストリングマッチング)で必要な面像の検索を行う。図表あるいは写真に対しては類似画像検索手段 7 により行う。

次に、図表3-3および写真3-4に対する類 ・ 公画像検索の一例について、第5図ないし第9図

- 1 1 -

る時に加工を施し、特徴情報を付加しておく。

ます、その登録動作を説明する。第6図は、画 像入力隻蹬 2.5 から送られる工次元二般の画像情 報の構造の例を示す図である。この画像情報は表 **示装置28によって画像として表示される。画像** 情報全体はM×N個の二値情報であり、本與施例 では彼0は白、1は黒を表すものとする。演算数 置27は、K×L個の小領域毎に各領域内の質1 の数を量子化した特徴量を第7図の形式にまとめ た特徴情報32を作成する。そして、特徴情報3 2とM×N個の面像情報33とを、記憶装置30 - に記憶する。このようにして記憶装置30には、 第5 既に示すように多数の画像に対する特徴情報 群34と画像情報群35とが記憶される。なお、 特徴情報32の先頭の画像器号31は、演算装置 27が複数の画像情報を識別するための一意な器 母である。

次に画像の検索動作を第9図に示す処理動作フローチャートにより説明する。制御入力装置28からは、一致判定の際の許容範囲として、利用者

を参照しつつ説明する。この例は本出願人の出願になる特願平1-113829号(発明者 広瀬 真)の明細書に聞示の技術によるものであり、必要とする画像を高速に検索できる利点のあるもの である。

類似画像検索を効率的に行うために、図表および写真を項目別ファイリング書積手段3へ登録す

-12-

が必要とする画像の数!が入力される(〇)。

海算装置 2.7 は、検索の条件となる画像が与えられると、登録の場合と同様にして検索の条件となる画像に対する特徴情報 a.x. を作成する(②)。

jを1に設定し、不一致度の小さい方からI番目の値を入れるレジスタD,の値をK×しに設定する(③)。

画像番号jの画像の特徴量 b j x t を算出する (④)。なお、第8図のように特徴量が登録時に 計算され画像のインデックスとして画像と一緒に 登録されている場合には、その値を配憶装置30 から読み出す。

ここで演算装置 2 7 は、画像番号 J 番から順に j 著目の画像と検索の条件となる画像との間の不 一致度 D J を計算していく (⑤)。

そしてD」が求まる皮に、すでに計算してある 不一致皮の小さい方から「番目の彼のD。とD」 とを比較する(®)。

D」> D:のときは、【番目までに入っていないので、次の両像についての処理に移るため、j

- 1 4 -

の値を1増加する(②)。

比較の結果、 D」≤ D」のときは、 D」を D」 の値で図き換える (⑦)。 不一致度が小さい方から! 番目までの画像の番号を記憶しておく (⑩)。 そして、次の画像についての処理に移るため、 j の値を〕 増加する (⑪)。

最後に、記憶してある全ての面像について不一 致度を計算し終ったときに、不一致度の小さい方 から1枚の面像を表示装置26に表示する。

ところで、特徴情報群34中における各画像の特徴情報と検索の条件となる画像の特徴情報との間の不一致度を計算する方法を説明する。特徴情報は、画像番号31とK行し列の行列で表せる画像の特徴量から成る。検索の条件となる画像の特徴量をa・1(k=1~K、l=1~L)、特徴情報群14の中の主番目の画像の特徴量を butt

(k=1~K、1=1~L)と表す。そして、各 小領域毎の領域内の1の数が2値に量子化されて いるとしたとき、条件となる画像とう発目の画像 との不一致度は次式で表される演算によって求め

- 1 5 -

見出し3~1がある場合には、その見出し3~1が接展配置かあるいは模長配置かを調べる(
の)。見出し3~1が接長配置のものであるときは、説み出した見出し文字を縦長配置手類に従って配置を行う(の)。 惯長配置のものであるときは、読み出した見出し文字を模長配置手順に従って配置する。

見出し3-1が縦長配置(®)および横長配置 (®)のいずれの場合でも、さらに他の見出し文字があるか否かを調べる(®)。

新たな見出し文字がなければ見出しの配置が終了し、本文の文字列の配置に移る。その際、次の行を文字列の右上端の座標として設定する(⑤)。

文字列がまだあるか否かを調べる(100)。文字列があればその文字列の右端からの余白と左側における所定のマージンとを比較して(100)、左側マージンの方が小さい間は、文字列を配置する(109)。文字列の配置は、現在の文字列の右端から文字幅だけ兼し引いた位置が次の文字列の右端となる(400)。

ることかできる。

D J = E E (aki D b jkt)

つまり、対応する要素制の排他的論理和の**総**和を 不一致度と定義する。 なお のは排他的論理和を表 す記号とする。

なお、各小領域毎の領域内の1の数が多値に量子化されているとしたとき、即ち、 B \*\*(と b ) \*\*( が多値のときは、条件となる画像と j 番目の画像との不一致度は次式で表される植算によって求められる。

 $D_{i} = \Sigma \Sigma \mid a_{ki} - b_{jki} \mid$ 

次に、検索した結果の画像を出力する際には、 見出し3-1、本文3-2、図表3-3、写真3 -4等文書全体の再配置処理を行う。第10図お よび第11図は再配置処理動作の手順を示すもの である。なお、第10図と第11図とはのと句に おいて接続される。

先ず、検索された文書画像に対応する響破手段 3 の見出し部の記憶位置を走査して見出し3 - 1 があるか否かを調べる(の)。

- 16 -

処理のにおいて、文字列配配の左側余白が、所定の左側マージンより小さくなった場合には、設
形の変更と文字列の右端再設定を行う(の)。そして、処理のと同様に文字列の配置を行う(の)。
処理ので配置すべき文字列がなくなると図数および写真の配置に移るが、まず図数、写真の配置の右上端の座標を設定する(の)。

処理ので検索結果の文帯画像に図表または写真があれば、それを配置すべき右端からの左側余白と左側における所定のマージンとを比較して(

図)、左側マージンの方が小さい間は、図表または写真の配置は、現在の図表または写真の右端から図表または写真の幅だけ差し引いた位置が次の図表または写真の右端となる(図)。

処理のにおいて、左側マージンの方が大きくなった場合には、段務の変更と図表または写真の右端再設定を行う(の)。そして、処理のと同様に図表または写真の配置を行う(の)。処理ので図表または写真がなくなると再配置は終了する(

特開平 3-14184(6)

**Ø**) 。

(発明の効果)

本発明によれば、文書画像における見出し、本文、図数、写真等異なる属性の領域を自動的に抽出、分離し、項目(属性領域)ごとに分けて書積するとともに、検索においては属性の領域ごとに適した検索方法により検索できるようにし、検索時の表示はその属性の領域のみとすることができる。

さらに、検索結果の文書画像を全体を項目ごとにそれぞれまとめて再配置するようにしたので、 文書中の無駄な余白を取り除きデータを圧縮させ ることができ、また表示に要する時間を短縮させ ることができる。

### 4 図面の簡単な説明

第1図は本発明の文書画像再配置ファイリング 装置の構成を示す図、第2図および第3図は領域 分離で抽象された各属性を項目別にファイルする 様子を示した図、第4図は領域分離手段のブロッ ク機成図、第5図は画像検索装置のブロック構成 図、第6図は二次元二節の画像情報の構造を示す図、第7図は特別情報の構造を示す図、第8図は特徴情報の構造を示す図、第8図は特徴情報群と画像情報群とを示す図、第9図は検 未動作時の処理フローチャート、第10図および 第11図は第1図図示における文書画像再配置処理手段8のフローチャートを示す。

1・・・文字画像入力手段

2 · · · 領域分離手段

3・・・項目別ファイル蓄積手段

4 • • • 文字認識手段:

5・・・ 画像圧縮手段

6・・・キーワード検索手段

7・・・類似面像検索手段

8 · · · 文書面像再配置処理手段

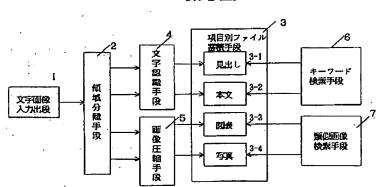
特許出願人 富士ゼロックス株式会社 代、理、人、弁理士 岩 上、昇

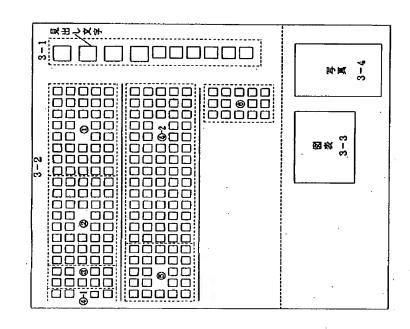
L #

- 19 --

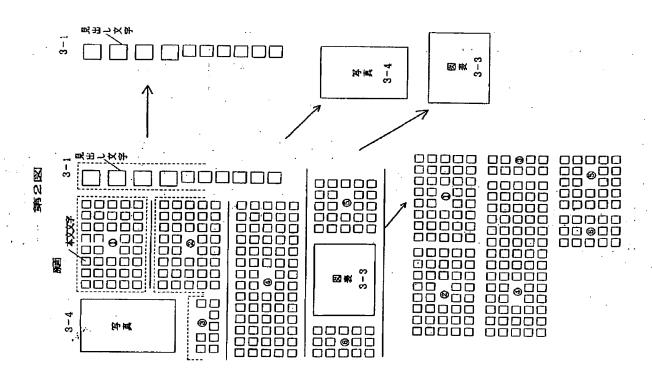
- 20 --

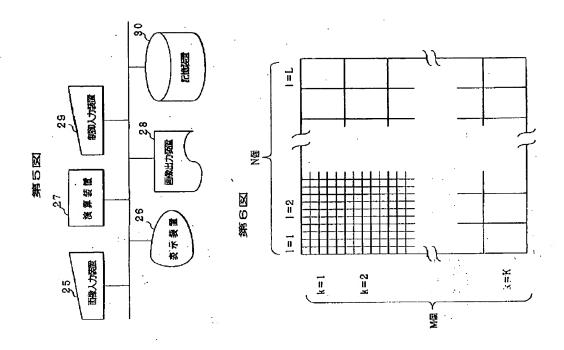
第 1 図

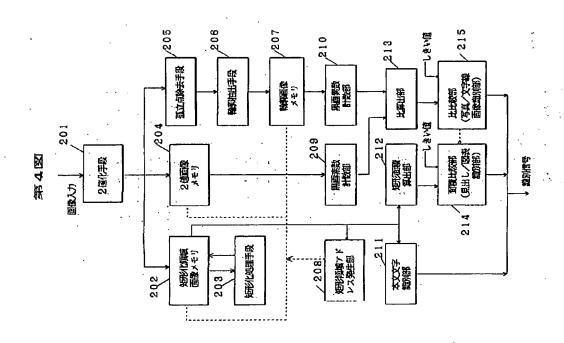


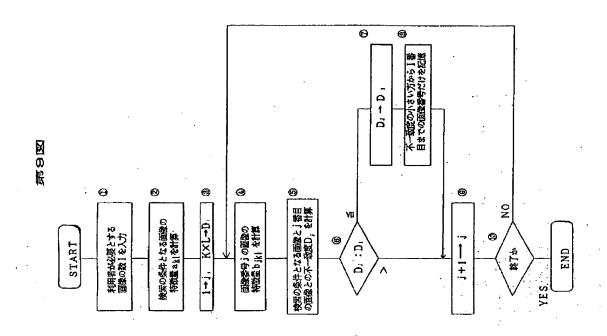


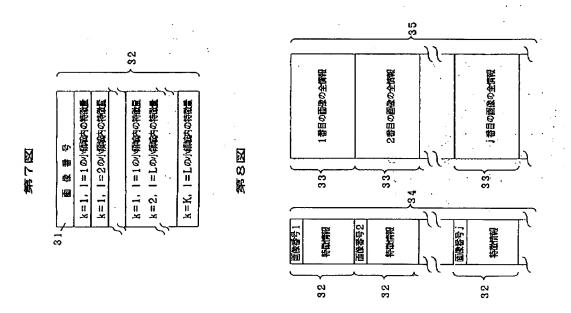
第3区











第 10 図

